

Woche 04 Praktische Anwendungsbeispiele: Den Gorilla vor lauter Hypothesen nicht sehen

Skript

Erarbeitet von
Joana Grah

Lernziele	1
Inhalt	2
Einstieg.....	2
Arithmetischer Mittelwert vs. Median	2
Das Ziegenproblem	3
Look at your data	5
Take-Home Message	6
Quellen	7
Weiterführendes Material.....	7
Disclaimer	8

Lernziele

- Anhand von Beispielen erläutern können, in welchen Fällen der arithmetische Mittelwert bzw. der Median als statistische Kennzahlen sinnvoll sind
- Das „Ziegenproblem“ erklären können
- Das Phänomen der selektiven Aufmerksamkeit im Zusammenhang mit wissenschaftlichem Arbeiten erklären können
- Erläutern können, warum es wichtig ist, sich Daten, die man analysieren möchte, genau anzuschauen (bzw. überhaupt anzuschauen) und sich nicht völlig auf hypothesengesteuertes wissenschaftliches Arbeiten zu versteifen

Inhalt

Einstieg

In diesem Video widmen wir uns zunächst noch einmal dem arithmetischen Mittelwert und dem Median und veranschaulichen anhand von Beispielen, wann welche von diesen statistischen Kennzahlen sinnvoll eingesetzt werden kann.

Dann illustrieren wir, warum wir häufiger Autos und seltener Ziegen gewinnen können, wenn wir Wahrscheinlichkeiten richtig verstehen und berechnen.

Außerdem zeigen wir am Beispiel eines Experiments, warum es so wichtig ist, sich immer mit den Daten, die man analysieren möchte, zu beschäftigen, sich diese gründlich anzuschauen und beim wissenschaftlichen Arbeiten nicht immer völlig hypothesengeleitet vorzugehen.

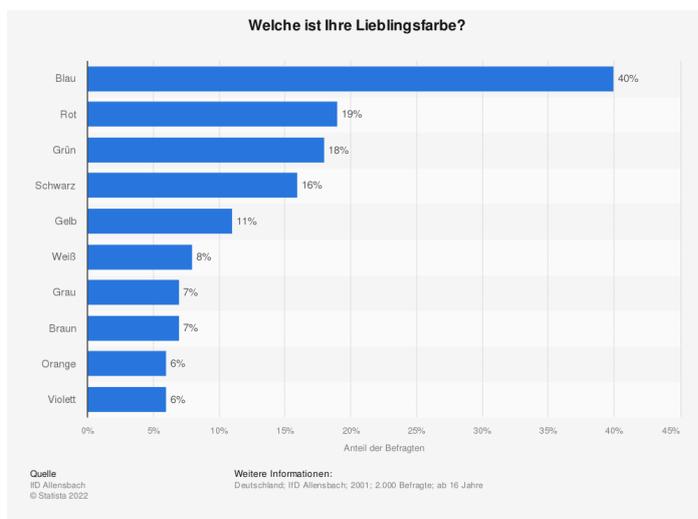
Arithmetischer Mittelwert vs. Median

Macht es eigentlich immer Sinn, Daten mit statistischen Kennzahlen zu analysieren? Ganz klar: nein. Wir schauen uns mal zwei Beispiele an.

Diese sind inspiriert von der Vorlesung „Calling Bullshit“ von Carl Bergstrom und Jevin West im Frühjahr 2017 an der University of Washington.

Quelle [1]

Einblendung Grafik Lieblingsfarbe



Quelle [2]

Hier sehen wir eine Umfrage vom Institut für Demoskopie Allensbach zur eigenen Lieblingsfarbe. Im Jahr 2001 wurden dazu in Deutschland 2.000 Menschen ab 16 Jahren befragt. Warum hier nicht die Gelegenheit genutzt wurde, die Balken im Diagramm in den entsprechenden Farben einzufärben, bleibt wohl ein Rätsel ...

Wir sehen also zum Beispiel, dass zwei von fünf Menschen, also 40 %, „Blau“ als ihre Lieblingsfarbe bezeichnen. Außerdem beliebt ist die Farbe „Rot“, die immerhin die Lieblingsfarbe von 19 % der Befragten ist, dicht gefolgt von „Grün“ mit 18 % und „Schwarz“ mit 16 %. Was auch auffällt: Offensichtlich gab es Mehrfachnennungen, denn die Prozentzahlen ergeben aufsummiert mehr als 100. Das liegt wohl daran, dass die Frage als offene Frage formuliert war.

Was ist, wenn wir diese Umfrage nun mit statistischen Kennzahlen analysieren möchten? Nehmen wir den arithmetischen Mittelwert. Können wir die durchschnittliche Lieblingsfarbe der Befragten berechnen? Wie soll das gehen, wenn wir keine Zahlen, sondern Farben gegeben haben? Die Farben mischen? Das macht natürlich nur wenig Sinn. Wir können in diesem Fall einfach keine sinnvolle Aussage treffen.

Wir müssen auf den Datentyp achten und Mittelwerte sind für kategoriale Daten in der Regel nicht geeignet.

Aber auch in anderen Situationen müssen wir genau überlegen, welche statistischen Kennzahlen Sinn machen. Wenn wir uns z. B. das durchschnittliche Einkommen in einer Stadt oder einem Land mit wenigen, aber sehr reichen Milliardär*innen angucken, dann wird der arithmetische Mittelwert viel höher sein als die meisten Einkommen in der Realität.

Einblendung Grafik Beispiel

Überlegen wir uns dazu ein kleines Beispiel. Stellen wir uns mal vor, wir machen eine Umfrage in der Düsseldorfer Innenstadt. Wir begegnen vier Menschen, die uns ihr Jahresbruttogehalt mitteilen:

20431 €, 48560 €, 56192 €, 81712 €.

Das ergibt ein Durchschnittsgehalt von 51724 €.

Jetzt biegt noch eine Person von der Kö um die Ecke und berichtet von einem Jahresbruttogehalt von 226500 €. Das erhöht den Durchschnitt drastisch auf 86679 €.

Um ein realistischeres Bild zu bekommen, schauen wir uns hier dann besser den Median an: Der beträgt nämlich 56192 €.

Das Ziegenproblem

Wir haben jetzt gesehen, wann uns statistische Kennzahlen einen falschen Eindruck vermitteln können oder unintuitiv sind, aber wie sieht es mit Wahrscheinlichkeiten aus? Diese begegnen uns allein im Alltag schon ziemlich oft, z. B. wenn wir in der Wetter-App

checken wollen, wie hoch die Regenwahrscheinlichkeit gerade ist, oder wenn uns beim Fußball-Schauen mal wieder mysteriöse Torwahrscheinlichkeiten angezeigt werden.

Einblendung TikTok-Video verpasstes Tor

Quelle [3]

Das war aber ´n Hundertprozentiger!

Ein sehr berühmtes Beispiel dafür, dass Wahrscheinlichkeiten manchmal nicht ganz so intuitiv zu verstehen sind, ist das sogenannte Ziegenproblem,

Einblendung TikTok-Video schreiende Ziege

Quelle [4]

auch bekannt als Monty-Hall-Problem. Monty Hall war Host der US-amerikanischen Spielshow „Let’s Make a Deal“. Die nicht mehr ganz so Jungen unter euch kennen vielleicht noch das deutsche Äquivalent „Geh auf’s Ganze“. In dieser Show finden sich Kandidat*innen u. a. in folgender Situation wieder:

Einblendungen Grafiken Ziegenproblem

Es gibt drei Tore, hinter denen sich ein Hauptpreis, sagen wir ein Auto, und zwei Trostpreise verbergen, sagen wir Ziegen, daher der Name Ziegenproblem. Nun sollen sie eines der drei Tore auswählen, von dem sie denken, dass sich dahinter das Auto befindet. Dieses wird nicht geöffnet, aber der Host, der weiß, was sich hinter den Toren befindet, öffnet stattdessen eines der beiden anderen Tore. Dort steht eine Ziege. Jetzt wird den Kandidat*innen vom Host die Option gegeben, das Tor noch einmal zu wechseln.

Was würdet ihr in der Situation tun? Was glaubt ihr, erhöht es eure Chancen auf den Auto-Gewinn, wenn ihr das Tor wechselt?

Viele Menschen würden intuitiv sagen, dass nach dem Öffnen des Tors mit der Ziege die Chancen 50:50 stehen und es unerheblich ist, ob man wechselt oder nicht. Das ist aber wahrscheinlichkeitstheoretisch betrachtet falsch. Hier müssen wir allerdings sehr vorsichtig sein, weil es ganz viele Annahmen in dem Modell gibt, die unklar sind und klar definiert werden müssen, z. B. ob der Host immer das Tor mit der Ziege öffnen würde, ob er den Wechsel allen Kandidat*innen anbietet usw. Wir nehmen für unser Beispiel in beiden Fällen „ja“ an.

Die richtige Antwort ist, dass ein Tor-Wechsel tatsächlich die Wahrscheinlichkeit verdoppelt, das Auto zu gewinnen. Wir können das am besten nachvollziehen, wenn wir mal alle möglichen Fälle durchgehen. Dazu nummerieren wir die Tore von 1 bis 3.

Wir nehmen o.B.d.A. (ohne Beschränkung der Allgemeinheit) an, dass eine Kandidatin Tor 1 gewählt hat. Mathematiker*innen sagen das gerne, um auszudrücken, dass wir uns jetzt nur einen von drei Fällen anschauen, weil die anderen beiden Fälle (Kandidatin wählt Tor 2 oder Tor 3) analog behandelt werden können. Jetzt gibt es drei Möglichkeiten:

1. Das Auto ist hinter Tor 1, hinter Tor 2 und Tor 3 befindet sich jeweils eine Ziege. Der Host öffnet ein beliebiges Tor mit einer Ziege. Die Kandidatin gewinnt beim Nicht-Wechseln und verliert beim Wechseln.
2. Das Auto ist hinter Tor 2. Der Host öffnet Tor 3 mit einer Ziege. Beim Nicht-Wechseln behält die Kandidatin die Ziege, beim Wechseln gewinnt sie das Auto.
3. Das Auto ist hinter Tor 3. Der Host öffnet Tor 2 mit einer Ziege. Beim Nicht-Wechseln behält die Kandidatin die Ziege, beim Wechseln gewinnt sie das Auto.

Die Kandidatin gewinnt also in einem von den drei Fällen, wenn sie bei Tor 1 bleibt, gewinnt aber in zwei Fällen, wenn sie wechselt.

Daher beträgt die Wahrscheinlichkeit das Auto beim Nicht-Wechseln zu gewinnen $\frac{1}{3}$ und das Auto beim Wechseln zu gewinnen $\frac{2}{3}$.

[Look at your data](#)

Jetzt möchten wir euch noch ein Experiment vorstellen, das an der HHU durchgeführt wurde.

Quelle [5]

Hintergrund war dabei die Frage, ob wir beim Analysieren von Datensätzen ein ähnliches Phänomen beobachten können, wie bei einem Experiment zur selektiven Aufmerksamkeit, das Ende der 90er Jahre von Psychologen in Harvard durchgeführt wurde.

Quelle [6]

Dabei wurde über 200 Student*innen u. a. ein Video gezeigt, in dem sie sich darauf fokussieren sollten, wie oft ein Basketball zwischen einem Team hin und her gespielt wurde. Mitten im Video lief ein Mensch im Gorillakostüm durch das Bild und klopfte sich auf die Brust. Tatsächlich bekam das ca. die Hälfte der Student*innen nicht mit, weil sie so konzentriert auf ihre Aufgabe waren.

Martin Lercher von der HHU und sein Co-Autor Itai Yanai stellten sich in ihrem Experiment

Quelle [7]

die Frage, ob dieses Phänomen auch auftritt, wenn sie Student*innen an der HHU die Aufgabe geben, einen Datensatz zu analysieren. Was diese nicht wussten – es gab zwei verschiedene Aufgabenstellungen. Eine Gruppe sollte drei vorgegebene Hypothesen testen, die andere Gruppe wurde nur gefragt, was sie aus dem Datensatz schließen können.

Quellen

- Quelle [1] UW iSchool. (2017, 11. Mai). *Calling Bullshit 4.2: Means and Medians* [Video]. YouTube.
- Quelle [2] <https://de.statista.com/statistik/daten/studie/50/umfrage/eigene-lieblingsfarbe/>
- Quelle [3] ransport. (2022, 9. August). *Wenn er den mit dem Kopf gemacht hätte!* 🤯
#ransport #bundesliga #fcbayern #frankfurt #fussball #football #soccer
#fail #ball #mueller #thomasmueller [Video]. TikTok.
- Quelle [4] mommyfarmer. (2022, 1. Oktober). *Fun farm fact: Bucks are gross*
#goats 🐐 #goatsoftiktok #bucksoftiktok #goatsounds #screaminggoat #funfarmfacts [Video]. TikTok.
- Quelle [5] <https://www.hhu.de/den-gorilla-vor-lauter-hypothesen-nicht-sehen>
- Quelle [6] Simons, D. J., & Chabris, C. F. (1999). Gorillas in our midst: Sustained inattentional blindness for dynamic events. *perception*, 28(9), 1059-1074.
- Quelle [7] Yanai, I., & Lercher, M. (2020). A hypothesis is a liability. *Genome Biology*, 21(1), 1-5.
- Quelle [8] Daniel Simons. (2010, 10. März). *selective attention test* [Video]. YouTube.

Weiterführendes Material

West, J. D., & Bergstrom, C. T. (2020). *Calling bullshit: the art of scepticism in a data-driven world*. Penguin UK.

Spiegelhalter, D. (2019). *The art of statistics: Learning from data*. Penguin UK.

D'ignazio, C., & Klein, L. F. (2020). *Data feminism*. MIT press.

Gencoglu, O., van Gils, M., Guldogan, E., Morikawa, C., Süzen, M., Gruber, M., ... & Huttunen, H. (2019). HARK Side of Deep Learning--From Grad Student Descent to Automated Machine Learning. *arXiv preprint arXiv:1904.07633*.

Elements of AI. Real world AI - Odds and probability. <https://course.elementsofai.com/3/1>

Disclaimer

Transkript zu dem Video „Woche 04 Praktische Anwendungsbeispiele: Den Gorilla vor lauter Hypothesen nicht sehen“, Joana Grah.

Dieses Transkript wurde im Rahmen des Projekts ai4all des Heine Center for Artificial Intelligence and Data Science (HeiCAD) an der Heinrich-Heine-Universität Düsseldorf unter der Creative Commons Lizenz [CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/) veröffentlicht. Ausgenommen von der Lizenz sind die verwendeten Logos, alle in den Quellen ausgewiesenen Fremdmaterialien sowie alle als Quellen gekennzeichneten Elemente.